

การเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทเทียมในการจำแนกโรคใบข้าว A Comparative Study of the Performance of CNN-Based Models for Rice Leaf Disease Classification

สกรณ บุษบง¹ และ แพรตะวัน จารุตัน^{2*}

Zagon Bussabong¹ and Praetawan Jarutan^{2*}

¹สาขาวิชาวิทยาการคอมพิวเตอร์ คณะวิทยาศาสตร์ มหาวิทยาลัยราชภัฏบุรีรัมย์ จังหวัดบุรีรัมย์ 31000

¹Program of Computer Science, Faculty of Science, Buriram Rajabhat University,
Buriram Province, 31000

²สาขาวิชาคอมพิวเตอร์ คณะวิทยาศาสตร์และเทคโนโลยี มหาวิทยาลัยราชภัฏสกลนคร จังหวัดสกลนคร 47000

²Program of Computer, Faculty of Science and Technology, Sakon Nakhon Rajabhat University,
Sakon Nakhon Province, 47000

Corresponding author Email: praetawan9925@snru.ac.th*

Received 30 May 2025, Accepted 2 October 2025, Published 7 October 2025

บทคัดย่อ

การวิจัยครั้งนี้มีวัตถุประสงค์เพื่อ 1) พัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมในการจำแนกโรคใบข้าวแบบไม่มีการเสริมข้อมูล และ 2) พัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมในการจำแนกโรคใบข้าวแบบมีการเสริมข้อมูล จากชุดข้อมูล RiceLeafBD Datasets ประกอบด้วยภาพทั้งหมด จำนวน 1,555 ภาพ แบ่งเป็น 4 ประเภทโรค ได้แก่ โรคใบไหม้จากแบคทีเรีย โรคใบไหม้จากเชื้อรา โรคใบจุดสีน้ำตาล และโรคไวรัสทั้งโกโร ซึ่งเป็นชุดข้อมูลออนไลน์สาธารณะในแพลตฟอร์ม Kaggle Dataset ทดลองด้วย 3 โครงข่ายประสาทเทียม ได้แก่ 1) InceptionNet-V2 2) MobileNet-V2 และ 3) EfficientNet-V2 ที่มีการปรับปรุงด้วยการเพิ่มองค์ประกอบอย่าง Squeeze-and-Excitation (SE) blocks เพื่อเรียนรู้ความสำคัญของแต่ละ Channel ให้ดีขึ้น โดยทั้ง 3 โครงข่ายได้ทดลองกับทั้ง 2 ชุดข้อมูล คือ ชุดข้อมูลพื้นฐานและชุดข้อมูลที่มีการเสริมข้อมูล ซึ่งการทดลอง Train และ Test โมเดล จำนวน 20 epoch และ 50 epoch สถิติที่ใช้ในการวิเคราะห์ข้อมูลได้แก่ Accuracy Precision Recall และ F1-score

ผลการพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมในการจำแนกโรคใบข้าวทั้งแบบไม่มีและมีการเสริมข้อมูล พบว่า โมเดลที่พัฒนาสามารถทำนายโรคใบข้าวได้ดีกว่าโมเดลพื้นฐาน (Base Model) ทั้ง 3 โครงข่าย โดยโครงข่ายประสาทเทียมที่ให้ค่าความถูกต้องสูงสุด ได้แก่ EfficientNet-V2 ในการทดลองแบบไม่มีการเสริมข้อมูล ได้ค่า Accuracy, Precision, Recall และ F1-score ตามลำดับ ดังนี้ 92.60%, 92.75%, 92.50% และ 92.25% และโมเดลที่มีการเสริมข้อมูล (EfficientNet-V2 + DA) ให้ค่าความถูกต้องในการจำแนกโรคใบข้าว ได้ค่า Accuracy, Precision, Recall และ F1-score ตามลำดับ ดังนี้ 95.50%, 95.75%, 95.75% และ 95.75% ซึ่งผลการทดลองในครั้งนี้ถือว่าโมเดลที่พัฒนามีประสิทธิภาพดีกว่าโมเดลพื้นฐานทุกกรณี

คำสำคัญ : การจำแนก การเสริมข้อมูล โครงข่ายประสาทเทียม โรคใบข้าว

ABSTRACT

The objectives of this study were: 1) to develop an artificial neural network model for classifying rice leaf diseases, and 2) to compare the performance of the models trained with augmented data against those trained without argumentation in classifying rice leaf diseases. The RiceLeafBD Dataset, consisted of 1,555 images divided into 4 disease categories: bacterial leaf blight, fungal leaf blight, brown leaf spot, and tungro virus, was used for this study. This dataset is publicly available on the Kaggle Dataset platform. Three neural networks, namely InceptionNet-V2, MobileNet-V2, and EfficientNet-V2, were experimented. These models were modified by adding Squeeze-and-Excitation (SE) blocks to better capture the importance of each channel. The experiments were conducted on two datasets: the baseline dataset and the augmented dataset. Model training and testing were performed for 20 and 50 epochs. The statistics used for data analysis were accuracy, precision, recall, and F1-score.

The results of model development and comparison of the efficiency of artificial neural networks in classifying rice leaf diseases with and without augmented data showed that the modified models achieved higher performance in classifying rice leaf diseases than the base models. Among the three modified models, EfficientNet-V2 achieved the highest accuracy. Without augmentation, EfficientNet-V2 revealed accuracy, precision, recall, and F1-score values of 92.60%, 92.75%, 92.50%, and 92.25%, respectively. With augmentation (EfficientNet-V2 + DA), the model achieved 95.50%, 95.75%, 95.75%, and 95.75% for accuracy, precision, recall, and F1-score, respectively. These results indicate that the developed models performed better than the base models in all cases.


Keywords: Classification, Data Augmentation, Neural Network Architectures, Rice Leaf Disease

บทนำ

ข้าวถือเป็นพืชเศรษฐกิจของหลายประเทศในภูมิภาคเอเชียตะวันออกเฉียงใต้ โรคที่เกิดกับต้นข้าว ใบข้าว หรือ รวงข้าวทำให้ผลผลิตข้าวลดลง 20-30 % (Ahmad et al., 2024) ประเทศไทยถือเป็นประเทศเกษตรกรรมการผลิตข้าวเป็นหนึ่งในกิจกรรมหลักทางเศรษฐกิจของประเทศ ซึ่งมีความสำคัญต่อความมั่นคงทางอาหารและรายได้ของเกษตรกร อย่างไรก็ตาม ปัญหาสำคัญที่ส่งผลกระทบต่อผลผลิตและคุณภาพของข้าวคือการเกิดโรคต่างๆ บนใบข้าว เช่น โรคกาบใบแห้ง โรคไหม้คอรวง โรคใบจุดสีน้ำตาล โรคขอบใบแห้ง และโรคใบขีดโปร่งแสง เป็นต้น ซึ่งโรคข้าวมีสาเหตุเกิดจากจุลินทรีย์หลายชนิด ได้แก่ เชื้อรา แบคทีเรีย ไวรัส และไส้เดือนฝอยซึ่งส่งผลกระทบต่อข้าวทั้งด้านปริมาณและคุณภาพ โดยเฉพาะโรคกาบใบแห้งที่เกิดจากเชื้อราในโซนภาคเหนือของประเทศ (กัญญารัตน์ และคณะ, 2563) และโรคใบไหม้จากเชื้อรา (จุฬาลักษณ์ และคณะ, 2567) ซึ่งหากไม่สามารถตรวจพบและจัดการได้อย่างทันท่วงที อาจนำไปสู่ความเสียหายอย่างรุนแรง (Spadaro et al., 2020) ในปัจจุบัน เทคโนโลยีปัญญาประดิษฐ์ โดยเฉพาะโครงข่ายประสาทเทียม (Artificial Neural Networks: ANN) ได้รับความนิยมอย่างแพร่หลายในด้านการประมวลผลภาพและการจำแนกประเภท เนื่องจากมีความสามารถในการเรียนรู้จากข้อมูลภาพจำนวนมากและสามารถดึงลักษณะเฉพาะของโรคจากภาพใบข้าวได้อย่างแม่นยำ อย่างไรก็ตาม โครงข่ายประสาทเทียมมีหลายรูปแบบ เช่น Convolutional Neural Network (CNN), Recurrent Neural Network (RNN), และ Multilayer Perceptron (MLP) ซึ่งแต่ละแบบมีจุดเด่นและข้อจำกัดที่แตกต่างกันในด้านความแม่นยำ ความเร็วในการประมวลผล และความสามารถในการเรียนรู้ลักษณะเฉพาะของข้อมูล (Chen et al., 2020) นอกจากปัจจัยการเลือกใช้โครงข่ายประสาทเทียมที่เหมาะสมกับประเภทงานแล้วปัจจัยด้านจำนวนของข้อมูลในชุดข้อมูล (Dataset) ที่เพียงพอหลากหลายจะช่วยเพิ่มประสิทธิภาพการทำงานของโมเดลในการฝึกให้ดียิ่งขึ้นได้ ซึ่งจากการศึกษางานวิจัยของ Rimi et al., (2025) ที่ใช้เป็นโมเดลพื้นฐาน พบว่า มีการปรับโมเดลในการทดลองเป็นแบบ Light Model ทำให้ลดจำนวนพารามิเตอร์ โมเดลมีขนาดเล็กลง

ทำงานเร็วขึ้น แต่ส่งผลให้ประสิทธิภาพความแม่นยำในการจำแนกลดลงด้วย รวมถึงจำนวนภาพต้นฉบับในชุดข้อมูลยังมีจำนวนน้อยส่งผลต่อการฝึกโมเดล การแก้ไขปัญหาจำนวนข้อมูลมีน้อยสามารถเพิ่มกระบวนการเสริมข้อมูล (Data Augmentation) เช่น การหมุนภาพ การพลิกภาพ การตัดภาพ เป็นต้น เพื่อช่วยเพิ่มความหลากหลายให้กับชุดข้อมูลได้ (Minaee et al., 2023)


ด้วยเหตุนี้ งานวิจัยมีวัตถุประสงค์เพื่อพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพของโครงข่ายประสาทเทียมในการจำแนกโรคใบข้าวแบบไม่มีการเสริมข้อมูลและมีการเสริมข้อมูลจากชุดข้อมูล RiceLeafBD Datasets จากประเทศบังกลาเทศที่มีประเภทของโรคใบข้าวเหมือนกับในประเทศไทย (Kanjamaneeesathian et al., 2009) แต่จำนวนภาพในชุดข้อมูลยังมีจำนวนน้อยผู้วิจัยจึงสนใจทดลองด้วยการเสริมข้อมูลเพื่อค้นหาโมเดลที่เหมาะสมและมีประสิทธิภาพสูงสุดในการจำแนกโรคใบข้าวและสามารถนำไปประยุกต์ใช้ในการพัฒนาแอปพลิเคชันหรืองานด้านเกษตรอัจฉริยะ ทั้งในระดับงานวิจัยและการใช้งานจริงในภาคสนาม โดยผลลัพธ์จากการศึกษานี้จะเป็นประโยชน์ต่อการพัฒนาเครื่องมือหรือระบบช่วยเหลือเกษตรกรในการวินิจฉัยโรคใบข้าวได้อย่างรวดเร็วและแม่นยำ



ภาพที่ 1 การใช้งานปัญญาประดิษฐ์ในการเกษตร

เอกสารและงานวิจัยที่เกี่ยวข้อง

1. **โครงข่ายประสาทเทียม (Convolutional Neural Network: CNN)** โครงข่ายประสาทเทียมนั้นถูกออกแบบมาให้มีการทำงานคล้ายกับสมองของมนุษย์ โดยการทำงานเบื้องหลังของโครงข่ายประสาทเทียมนั้นมีหน่วยย่อยที่ทำงานคล้ายกับเซลล์ประสาทของมนุษย์ เรียกว่า Node ซึ่ง Node สามารถรวมตัวกันจำนวนหนึ่งเรียงตัวเป็นชั้น จะเรียกว่า Layer โดยแต่ละ Node จะมีขั้นตอนการทำงานแบ่งหน้าที่ตาม Layer เช่น Input Layer, Hidden Layer และ Output Layer เป็นต้น




ภาพที่ 2 สถาปัตยกรรมโครงข่ายประสาทเทียม

2. โครงข่าย InceptionNet หรือ GoogLeNet เป็นโครงข่ายประสาทเทียมแบบลึกที่พัฒนาโดย Google สำหรับการรู้จำภาพโดยเปิดตัวครั้งแรกในปี 2014 ในการแข่งขัน ImageNet (ILSVRC) ซึ่งมีจุดเด่นอยู่ที่ Inception Module ซึ่งรวมการประมวลผลจากหลายขนาดของ Convolution เช่น 1x1 3x3 5x5 และ Pooling ภายในเลเยอร์เดียวเพื่อให้ได้การเรียนรู้ที่หลากหลาย โดยยังคงประสิทธิภาพการประมวลผลไว้ผ่านเทคนิคการลดมิติด้วย 1x1 Convolution ทำให้สามารถจำแนกรูปภาพได้อย่างมีประสิทธิภาพสูง ทั้งนี้ InceptionNet ได้ถูกพัฒนาต่อเนื่องหลายรุ่น เช่น Inception-v2, Inception-v3 และ Inception-v4 เพื่อเพิ่มความแม่นยำและลดความซับซ้อนของโมเดล (Szegedy et al., 2015)

3. โครงข่าย MobileNet เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมที่พัฒนาโดย Google เพื่อรองรับการประมวลผลบนอุปกรณ์ที่มีข้อจำกัดด้านทรัพยากร เช่น สมาร์ทโฟน โดยมีจุดเด่นคือการใช้เทคนิค Depthwise Separable Convolution ซึ่งช่วยลดจำนวนพารามิเตอร์และการคำนวณอย่างมากเมื่อเทียบกับ Convolution แบบดั้งเดิม ทำให้โมเดลมีขนาดเล็กและรวดเร็วขึ้นโดยยังคงประสิทธิภาพในการจำแนกรูปภาพได้ดี MobileNet ยังมีพารามิเตอร์ที่ปรับขนาดได้ เช่น Width Multiplier และ Resolution Multiplier เพื่อให้ผู้ใช้สามารถเลือกสมดุลระหว่างความเร็วและความแม่นยำได้ตามความต้องการ (Howard et al., 2017)

4. โครงข่าย EfficientNet เป็นสถาปัตยกรรมโครงข่ายประสาทเทียมแบบ Convolutional Neural Network ที่พัฒนาโดย Google ในปี 2019 โดยเน้นการเพิ่มประสิทธิภาพของโมเดลผ่านแนวคิด Compound Scaling ซึ่งปรับความลึก (Depth) ความกว้าง (Width) และความละเอียดของภาพ (Resolution) ไปพร้อมกันอย่างสมดุลแทนการขยายเพียงมิติใดมิติหนึ่ง ส่งผลให้ EfficientNet มีความแม่นยำสูงในการจำแนกรูปภาพ ในขณะที่ใช้พารามิเตอร์และพลังประมวลผลน้อยกว่ารุ่นก่อนหน้า เช่น ResNet และ Inception อย่างมีนัยสำคัญ โดย EfficientNet-B0 ถูกสร้างขึ้นจาก Neural Architecture Search และขยายเป็น EfficientNet-B1 ถึง B7 เพื่อรองรับการใช้งานที่หลากหลาย (Tan and Le, 2019)

5. การเสริมข้อมูล (Data Augmentation) คือ เทคนิคในกระบวนการ เตรียมข้อมูล (Data Preprocessing) ที่ใช้ในการสร้างข้อมูลใหม่จากข้อมูลที่มีอยู่ เพื่อเพิ่มปริมาณข้อมูลฝึกสอน (Training Data) ให้มากขึ้น โดยไม่ต้องเก็บข้อมูลใหม่จริงๆ เทคนิคนี้นิยมมากในงาน Machine Learning โดยเฉพาะ Deep Learning เช่น การจำแนกภาพ เสียง หรือข้อความ ตัวอย่างการทำ Data Augmentation เช่น การหมุนภาพ การยืดหดภาพ การปรับความสว่าง การตัดภาพ เป็นต้น (Yang et al., 2024)



ภาพที่ 3 การเสริมข้อมูลงานรูปภาพ

6. โรคใบขาว คือโรคที่เกิดจากเชื้อรา แบคทีเรีย หรือไวรัส ซึ่งส่งผลกระทบต่อใบของต้นข้าว ทำให้ลดประสิทธิภาพในการสังเคราะห์แสงและส่งผลต่อผลผลิตโดยรวม การระบุและจำแนกโรคใบขาวอย่างแม่นยำมีความสำคัญอย่างยิ่งในการควบคุมและป้องกันการแพร่กระจายของโรค ในปัจจุบัน มีการศึกษาและพัฒนาโมเดลการเรียนรู้เชิงลึก (Deep Learning) เช่น Convolutional Neural Networks (CNN) เพื่อช่วยในการจำแนกโรคใบขาวจากภาพถ่าย (Dutta et al., 2024)

SN	Class Name	Description	Sample Images
1	Bacterial Blight	Dimension - 300*300	
		Formats - jpg	
		Quantity - 1584	
2	Blast	Dimension - 300*300	
		Formats - jpg	
		Quantity - 1440	
3	Brown Spot	Dimension - 300*300	
		Formats - jpg	
		Quantity - 1600	
4	Tungro	Dimension - 300*300	
		Formats - jpg	
		Quantity - 1308	

ภาพที่ 4 ภาพโรคใบขาว

7. งานวิจัยที่เกี่ยวข้อง

ด้านโครงข่ายประสาทเทียม Hossain et al. (2021) ทำการศึกษาการเรียนรู้แบบถ่ายโอนกับโครงข่ายประสาทเทียมแบบคอนโวลูชันแบบลึกเพื่อปรับปรุงประสิทธิภาพการจำแนกประเภทโรคใบพืช โดยใช้สถาปัตยกรรมการเรียนรู้เชิงลึกที่มีประสิทธิภาพ ทดลองบนชุดข้อมูลภาพใบพืชแบบเต็มและบางส่วน นำเสนอผ่านโมเดลการเรียนรู้ ได้แก่ MobileNet VGG16 VGG19 และ AlexNet ยังแสดงให้เห็นถึงผลลัพธ์ที่มีแนวโน้มในการจำแนกโรคใบพืชที่มีความถูกต้องและความแม่นยำสูง ซึ่งโมเดล MobileNet ที่มีการปรับปรุง มีความแม่นยำสูงที่สุดที่ 99.55% และคะแนน F1 97.07% ทำให้เหมาะสำหรับระบบคอมพิวเตอร์ช่วยวินิจฉัยโรคใบพืช

ด้านการเสริมข้อมูล Fawaiq et al. (2023) เสนอเทคโนโลยีสารสนเทศที่ใช้ในการระบุโรคโดยใช้การประมวลผลภาพและการจำแนกภาพ ชุดข้อมูลในการทดลองนำมาจากที่เก็บข้อมูลสาธารณะ และทำการเสริมข้อมูลในงานวิจัย เพื่อเพิ่มความแม่นยำในการฝึกของชุดข้อมูลตามแนวทางระบบตรวจจับโรคโดยใช้เมธอดการเรียนรู้เชิงลึกโดยใช้ Convolutional Neural Network (CNN) และสถาปัตยกรรมการเรียนรู้การถ่ายโอนหลายแบบ ได้แก่ VGG16 NASNetMobile และ Xception สำหรับการตรวจจับโรคใบข้าว ผลการทดลองที่ดีที่สุดได้มาโดยใช้สถาปัตยกรรม Xception ซึ่งค่าความแม่นยำในการฝึกคือ 99.13% ความแม่นยำในการตรวจสอบคือ 97.22% และความแม่นยำในการทดสอบคือ 97.22%

ด้านโรคใบข้าว Haque et al. (2022) ได้ทำการศึกษาและสำรวจเอกสารพบว่า จากความก้าวหน้าอย่างต่อเนื่องของเทคโนโลยีการตรวจจับวัตถุ อัลกอริทึมของตระกูล YOLO มีความแม่นยำสูงเป็นพิเศษและความเร็วที่ดี จึงถูกนำมาใช้ในการจดจำจากต่างๆ เพื่อสร้างระบบตรวจสอบโรคใบข้าว ผู้วิจัยจึงได้สร้างคำอธิบายประกอบชุดข้อมูลที่รวบรวมได้ 1,500 ชุด และเสนอวิธีการจำแนกและตรวจจับโรคใบข้าวโดยอิงตามการเรียนรู้เชิงลึก YOLOv5 จากนั้นฝึกอบรมและประเมินโมเดล YOLOv5 ผลลัพธ์ของการจำลองแสดงให้เห็นผลลัพธ์การตรวจจับวัตถุที่ดีขึ้นสำหรับเครือข่าย YOLOv5 ระดับความแม่นยำในการจดจำ การเรียกคืน ค่า mAP และคะแนน F1 ที่ต้องการคือ 90% 67% 76% และ 81% ตามลำดับ ซึ่งถือเป็นตัวชี้วัดประสิทธิภาพ

วิธีการวิจัย

การศึกษาค้นคว้าพัฒนาโมเดลโครงข่ายประสาทเทียมหลายรูปแบบในการจำแนกโรคใบข้าวจากภาพถ่าย มีขั้นตอนในการวิจัยดังนี้

1. การศึกษารวบรวมข้อมูลภาพใบข้าว

1.1 ศึกษาข้อมูลจากแหล่งข้อมูลสาธารณะ ได้แก่ แพลตฟอร์ม Kaggle ด้วยชุดข้อมูล RiceLeafBD Datasets (Rimi et al., 2025) ที่ประกอบด้วยรูปภาพทั้งหมด 1,555 ภาพ แบ่งเป็น 4 ประเภทโรค ได้แก่ โรคใบไหม้จากแบคทีเรีย โรคใบไหม้จากเชื้อรา โรคใบจุดสีน้ำตาล และโรคไวรัสทั้งกร ดังแสดงในภาพที่ 5



ภาพที่ 5 ตัวอย่างภาพข้อมูลโรคใบข้าว

1.2 ทำการจัดกลุ่มและระบุป้ายกำกับ (Labeling) ให้ชัดเจน

2. การเตรียมข้อมูล

2.1 ปรับขนาดภาพให้อยู่ในรูปแบบที่เหมาะสมกับโครงข่ายประสาทเทียมแต่ละประเภท ในการทดลองใช้ขนาดภาพ 224x224 ซึ่งเป็นขนาดมาตรฐาน (Sandler et al., 2018)

2.2 แปลงข้อมูลให้อยู่ในรูปแบบ Tensor และทำการ Normalize ค่าพิกเซลอยู่ในช่วง [-1, 1]

2.3 แบ่งข้อมูลออกเป็น 3 ชุด (Train: 80%, Val+Test: 20%) ได้แก่

1. ชุดฝึกอบรม (Training set)
2. ชุดตรวจสอบ (Validation set)
3. ชุดทดสอบ (Test set)

2.4 การเพิ่มความหลากหลายของข้อมูล (Data Augmentation) เนื่องจากผลการทดลองของ Rimi et al. (2025) กับชุดข้อมูลเดิมที่มีจำนวนทั้งหมด 1,555 ภาพ พบว่า ผลการจำแนกโรคใบข้าวยังมีความคลาดเคลื่อน ผู้วิจัยและคณะจึงทดลองเพิ่มความหลากหลายให้ชุดข้อมูล ด้วย 2 เทคนิค ได้แก่ การหมุนภาพ (Rotation) และการกลับภาพ (Flipping)

3. การเลือกโครงข่ายประสาทเทียมที่จะใช้ในการทดลอง

3.1 เลือกโครงข่ายประสาทเทียมตามงานวิจัยของ Rimi et al. (2025) ที่มีการทดลองตาม Transfer Learning บน 3 โมเดล ดังนี้ InceptionNet-V2, MobileNet-V2, และ EfficientNet-V2 เนื่องจากทั้ง 3 โมเดล เป็นโมเดลพื้นฐานที่มีการ Scale อย่างมีประสิทธิภาพ มีขนาดของโมเดลเล็กและทำงานเร็วเหมาะสมสำหรับใช้งานในอุปกรณ์ขนาดเล็ก เช่น สมาร์ทโฟน โดรน ยังมีนักวิจัยหลายคนใช้แบบจำลองเหล่านี้เป็นแบบจำลองพื้นฐานพร้อมแนะนำถึงความเหมาะสมที่สุดสำหรับชุดข้อมูลภาพ

3.2 กำหนดพารามิเตอร์ที่ใช้สำหรับแต่ละโมเดลตามการทดลองของ Base Model ที่มีการกำหนดค่า ดังนี้ Learning Rate = 0.0001 Batch Size = 32 Epoch 20, 50

3.3 สภาพแวดล้อมในการทดลอง

ตารางที่ 1 ข้อมูลคุณสมบัติของเครื่องคอมพิวเตอร์ ซอฟต์แวร์และไลบรารีที่ใช้ในการทดลอง (Dai et al., 2019)

เครื่องคอมพิวเตอร์ตามสเปกดังต่อไปนี้	ซอฟต์แวร์และไลบรารีที่ใช้
CPU: Apple M1 Max	OS: MacOS Sequoia 15.5
RAM: 32 GB	Python: 3.12.1 (จัดการ Environment ด้วย VS-Code)
Storage: SSD 1 TB	TensorFlow: 2.19.0
	ไลบรารีที่เกี่ยวข้อง: NumPy, OpenCV, Albumentations, Matplotlib, Scikit-Learn

4. การฝึกสอนโมเดล (Model Training)

4.1 ทำการฝึกสอนโมเดลแต่ละแบบด้วยชุดข้อมูลฝึกอบรม

4.2 ใช้ชุด Validation เพื่อติดตามการเรียนรู้ ปรับค่าพารามิเตอร์เพื่อลด Overfitting

5. การทดสอบโมเดล (Model Evaluation)

5.1 ทดสอบความแม่นยำของโมเดลแต่ละแบบด้วยชุดข้อมูลทดสอบ

5.2 ประเมินผลด้วยเกณฑ์ Accuracy, Precision, Recall และ F1-score โดยค่า Accuracy: บ่งบอกว่าโมเดลทำนายถูกต้องทั้งหมดกี่เปอร์เซ็นต์ ค่า Precision: ประเมินว่าโมเดลมีโอกาสแจ้งเตือนผิด หรือ "วินิจฉัยโรคที่ไม่มีจริง" หรือไม่ ค่า Recall: ประเมินว่าภาพในแต่ละกลุ่มโรค ภาพที่เป็นโรคจริงๆ โมเดลตรวจพบได้กี่ภาพ และ ค่า F1-score: เป็นค่าเฉลี่ยถ่วงน้ำหนักระหว่าง Precision และ Recall เพื่อวัดความสามารถของโมเดลแบบสมดุล

6. การเปรียบเทียบผลลัพธ์

6.1 วิเคราะห์และเปรียบเทียบประสิทธิภาพของโมเดลพื้นฐานกับโมเดลปรับปรุงแต่ละแบบ

6.2 พิจารณาความเหมาะสมในการนำไปใช้งานจริง เช่น ในแอปพลิเคชันบนโทรศัพท์มือถือหรือระบบตรวจโรคใบข้าวอัตโนมัติ

7. สรุปผลการทดลองและข้อเสนอแนะ

7.1 สรุปว่าโมเดลใดมีประสิทธิภาพดีที่สุดในการจำแนกโรคใบข้าว

7.2 วิเคราะห์ข้อจำกัด และเสนอแนะแนวทางการปรับปรุงในอนาคต


ผลการวิจัย และวิจารณ์ผลการวิจัย

1. ผลการพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมแบบไม่มีการเสริมข้อมูล บนชุดข้อมูล RiceLeafBD Datasets


ตารางที่ 2 ผลการพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมแบบไม่มีการเสริมข้อมูล

Model	Accuracy (%)	
	20 Epoch	50 Epoch
MobileNet-V2 (Rimi et al., 2025)	-	89.75
MobileNet-V2 (Our)	68.72	90.15
InceptionNet-V2 (Rimi et al., 2025)	-	85.00
InceptionNet-V2 (Our)	66.50	90.05
EfficientNet-V2 (Rimi et al., 2025)	-	91.50
EfficientNet-V2 (Our)	72.66	92.60

จากตารางที่ 2 พบว่า โมเดลที่พัฒนาทั้ง 3 โครงข่ายให้ค่า Accuracy สูงกว่า Base Model ทุกกรณี และโครงข่าย EfficientNet-V2 ที่ปรับปรุงให้ค่า Accuracy สูงสุด เท่ากับ 92.60%



ภาพที่ 6 ค่า Accuracy and Loss Curve of EfficientNet-V2 Model




ภาพที่ 7 แสดงค่า Confusion Matrix of EfficientNet-V2 Models

2. ผลการพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมแบบมีการเสริมข้อมูล (Data Augmentation: DA) บนชุดข้อมูล RiceLeafBD Datasets


ตารางที่ 3 ผลการพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมแบบมีการเสริมข้อมูล

Model	Accuracy (%)	
	20 Epoch	50 Epoch
MobileNet-V2 (Rimi et al., 2025)	-	89.75
MobileNet-V2 + DA (Our)	76.17	91.75
InceptionNet-V2 (Rimi et al., 2025)	-	85.00
InceptionNet-V2 + DA (Our)	70.50	90.76
EfficientNet-V2 (Rimi et al., 2025)	-	91.50
EfficientNet-V2 + DA (Our)	81.03	95.50

จากตารางที่ 3 พบว่า โมเดลที่ปรับปรุงทั้ง 3 โครงข่ายให้ค่า Accuracy สูงกว่า Base Model ทุกกรณี และโครงข่าย EfficientNet-V2 + DA ที่ปรับปรุงให้ค่า Accuracy สูงสุด เท่ากับ 95.50%



ภาพที่ 8 ค่า Accuracy and Loss Curve of EfficientNet-V2 + DA Model




ภาพที่ 9 แสดงค่า Confusion Matrix of EfficientNet-V2 + DA Models

3. ผลการพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพของ 3 โมเดล

ตารางที่ 4 ผลการเปรียบเทียบ Accuracy ของ 3 โมเดลแบบไม่มีการเสริมข้อมูล


Model	MobileNet-V2	InceptionNet-V2	EfficientNet-V2
Base Model	89.75	85.00	91.50
Our Model	90.15	90.05	92.60



ภาพที่ 10 แสดงกราฟเปรียบเทียบประสิทธิภาพของ 3 โมเดล แบบไม่มีการเสริมข้อมูล

ตารางที่ 5 ผลการเปรียบเทียบ Accuracy ของ 3 โมเดลแบบมีการเสริมข้อมูล

Model	MobileNet-V2	InceptionNet-V2	EfficientNet-V2
Base Model	89.75	85.00	91.50
Our Model	91.75	90.76	95.50



ภาพที่ 11 แสดงกราฟเปรียบเทียบประสิทธิภาพของ 3 โมเดล แบบมีการเสริมข้อมูล

4. วิจัยผลการวิจัย

การปรับสถาปัตยกรรมของ MobileNet-V2 เพื่อเพิ่มความแม่นยำโดยไม่เพิ่มขนาดโมเดลเน้นที่การปรับปรุงภายในโครงสร้าง Inverted Residual Blocks โดยเพิ่มองค์ประกอบอย่าง Squeeze-and-Excitation (SE) Blocks เพื่อเรียนรู้ความสำคัญของแต่ละ Channel ได้ดี ช่วยเพิ่มประสิทธิภาพของโมเดลโดยไม่ต้องเพิ่มพารามิเตอร์ แสดงให้เห็นถึงการปรับปรุง Accuracy ที่ชัดเจนโดยยังคงความเบาของโมเดลไว้สอดคล้องกับงานวิจัยของ Howard et al. (2019) การปรับปรุงสถาปัตยกรรมของ Inception-v2 เพื่อเพิ่มความแม่นยำสามารถทำได้โดยใช้การเพิ่ม Squeeze-and-Excitation (SE) Blocks เพื่อเรียนรู้น้ำหนักของแต่ละ Feature Channel อย่างมีประสิทธิภาพ นอกจากนี้ การเพิ่ม Residual Connections ภายใน Inception modules ช่วยให้การฝึกโมเดลที่ลึกขึ้นโดยไม่สูญเสีย Gradient ในขณะที่เรียนรู้สอดคล้องกับงานวิจัยของ Hu et al. (2018) และการปรับปรุงสถาปัตยกรรมของ EfficientNet-V2 โดยการขยาย Receptive Field ผ่าน Dilated Convolution โดยไม่เพิ่มพารามิเตอร์ของโมเดล ช่วยเพิ่มความแม่นยำของการจำแนกได้ สอดคล้องกับงานวิจัยของ Hou et al. (2021)

การเสริมข้อมูล หรือการทำ Data Augmentation ช่วยเพิ่มประสิทธิภาพของโมเดลโดยการสร้างความหลากหลายของข้อมูล ซึ่งช่วยลด Overfitting และเพิ่มความสามารถในการ Generalize โดยเฉพาะเทคนิคใหม่ๆ อย่าง Mixup CutMix และ RandAugment ที่ได้รับการพิสูจน์แล้วว่าสามารถเพิ่ม Accuracy ได้อย่างมีนัยสำคัญโดยไม่ต้องเพิ่มขนาดของโมเดลหรือข้อมูลจริง สอดคล้องกับงานวิจัยของ Cubuk et al. (2020)

การใช้ Dataset จากแหล่งข้อมูลสาธารณะมีข้อดี คือ สะดวกและประหยัดเวลาแต่ก็มีข้อจำกัดสำคัญโดยเฉพาะเมื่อชุดข้อมูลนั้นไม่สะท้อนบริบทเชิงท้องถิ่น (Local Context) ซึ่งอาจส่งผลให้โมเดลที่ฝึกได้ ไม่สามารถใช้งานจริงได้อย่างมีประสิทธิภาพหรือยังมีความผิดพลาดในการจำแนกโรคของโมเดล เช่น ลักษณะใบ สี และลักษณะโรคอาจแตกต่างจากของจริงในพื้นที่ปลูกจริงของท้องถิ่นรวมถึงความถูกต้องของ Label ในชุดข้อมูลสาธารณะอาจไม่แม่นยำหรือไม่ผ่านผู้เชี่ยวชาญท้องถิ่น สอดคล้องกับงานวิจัยของ Xu et al. (2024)

สรุปผลการวิจัย

ผลการพัฒนาโมเดลและเปรียบเทียบประสิทธิภาพโครงข่ายประสาทเทียมในการจำแนกโรคใบข้าวแบบมีและไม่มี การเสริมข้อมูล ด้วยโครงข่ายประสาทเทียม 3 โครงข่าย ได้แก่ MobileNet-V2 Inception-v2 และ EfficientNet-V2 ซึ่งทั้ง 3 โครงข่ายทดลองกับชุดข้อมูลพื้นฐาน 1,555 ภาพ และชุดข้อมูลที่มีการเสริมข้อมูล ด้วย 2 เทคนิค ได้แก่ การหมุนภาพ และการกลับภาพ ได้ภาพเพิ่มขึ้นเป็น 3,110 ภาพ โดยโครงข่ายประสาทเทียมที่ให้ค่าความถูกต้องสูงสุด ได้แก่ EfficientNet-V2 ที่มีการเสริมข้อมูล (EfficientNet-V2 + DA) ให้ค่าความถูกต้องในการจำแนกโรคใบข้าว ได้ค่า Accuracy Precision Recall และ F1-score ตามลำดับดังนี้ 95.50% 95.75% 95.75% และ 95.75%

นอกจากนี้ในการวิจัยได้ทำการปรับปรุง Base model ทั้ง 3 โครงข่าย ดังนี้ โดย 2 โครงข่าย ได้แก่ MobileNet-V2 และโครงข่าย Inception-v2 ปรับปรุงโดยการเพิ่มองค์ประกอบอย่าง Squeeze-and-Excitation (SE) Blocks เพื่อเรียนรู้ความสำคัญของแต่ละ Channel ส่วนโครงข่าย EfficientNet-V2 ปรับปรุงโดยการขยาย Receptive Field ผ่าน Dilated Convolution พบว่า โครงข่าย MobileNet-V2 ที่ปรับปรุงและการเสริมข้อมูล ในการทดลองรันจำนวน 50 Epoch ให้ค่า Accuracy เท่ากับ 90.15% และ 91.75% ตามลำดับ ส่วนโครงข่าย InceptionNet-V2 ที่ปรับปรุงและเสริมข้อมูล ให้ค่า Accuracy เท่ากับ 90.05% และ 90.76% ตามลำดับ และโครงข่าย EfficientNet-V2 ที่ปรับปรุงและเสริมข้อมูลให้ค่า Accuracy เท่ากับ 92.60% และ 95.50 % ตามลำดับ ซึ่งสรุปว่าทุกโครงข่ายที่ปรับปรุงทั้งไม่มีและมีการเสริมข้อมูลสามารถจำแนกภาพโรคใบข้าวได้ดีกว่า Base Model จากค่า Accuracy

การนำโมเดลไปประยุกต์ใช้งาน ได้แก่ นำไปวิเคราะห์ภาพใบข้าวจากกล้องมือถือ โดรน หรืออุปกรณ์ IoT ได้ทันทีหรือพัฒนาแอปพลิเคชันช่วยตรวจจับโรคตั้งแต่ระยะเริ่มต้นก่อนที่จะการระบาดจะลุกลาม รวมถึงลดภาระของเกษตรกรในการสังเกตอาการด้วยตนเองหรือสามารถ Fine-Tune ไปใช้กับพืชอื่น เช่น มันสำปะหลัง ข้าวโพด อ้อย ฯลฯ ได้

ข้อเสนอแนะ

1. ข้อเสนอแนะการใช้งานจริง

- 1) ควรติดตั้งซอฟต์แวร์และไลบรารีในเวอร์ชันเดียวกันกับที่โมเดลใช้ในการทดลอง
- 2) สามารถรันงานได้ทั้งบนแพลตฟอร์ม Google Colab หรือ Visual Studio Code
- 3) ควรพัฒนาต่อยอดเป็นแอปพลิเคชันบนสมาร์ตโฟนเพื่อช่วยเกษตรกรในการใช้งานเชิงพื้นที่จริง

2. ข้อเสนอแนะในการพัฒนาต่อเชิงเทคนิค

- 1) ควรเพิ่มประเภทของโครงข่ายให้มากขึ้นเพื่อเปรียบเทียบประสิทธิภาพ
- 2) ควรปรับปรุงกลไกการใส่ใจ (Attention mechanism) ในการสกัดคุณลักษณะของภาพเพื่อเพิ่มประสิทธิภาพความแม่นยำในการจำแนกภาพ
- 3) ควรเพิ่มการเสริมข้อมูลภาพด้วยวิธีการที่หลากหลายในการเปรียบเทียบประสิทธิภาพ
- 4) ควรใช้ Explainable AI (XAI) ช่วยเพิ่มการอธิบายผลลัพธ์การทำงานที่ซับซ้อนของโมเดล และตรวจสอบความผิดพลาดหรือรองรับข้อกำหนดทางจริยธรรมหรือกฎหมาย

กิตติกรรมประกาศ

ขอขอบพระคุณนักวิจัย Rimi และคณะที่ได้ศึกษาทดลองโครงข่ายประสาทเทียมแบบ Transfer Learning และได้เผยแพร่ชุดข้อมูลโรคใบขาวสำหรับใช้ในการทดลองพัฒนาประสิทธิภาพการจำแนกโรคใบขาวในครั้งนี้

เอกสารอ้างอิง

- กัญญารัตน์ สมเพ็ชร, พัชรวิภา ใจจักรคำ, และอรอุมา เพี้ยชัย. (2563). การจัดจำแนกชนิด และการใช้สารเคมีควบคุมเชื้อรา *Rhizoctonia* species สาเหตุโรคกาบใบแห้งของข้าว. *วารสารวิทยาศาสตร์และนวัตกรรมการเกษตร*, 51(2), 122-138.
- จุฬาลักษณ์ มุ่งมาตร, ดุสิต อธิวัฒน์, และวิลาวรรณ เชื้อบุญ. (2567). การยับยั้งเชื้อสาเหตุโรคใบไหม้และส่งเสริมการเจริญเติบโตของข้าวต่างพันธุ์ด้วยแบคทีเรีย. *วารสารมหาวิทยาลัยราชภัฏร้อยเอ็ด: วิทยาศาสตร์และเทคโนโลยี*, 5(2), 58-72.
- Ahmad, R., Ansari, M. H., Thakur, M. B., Anwer, A., Singh, S. N., Kunal, G., Singh, P., Minnatullah, M. (2024). A review on emerging insights into bacterial leaf blight of rice: diagnostics, climate dynamics, and economic impact. *Agricultural Mechanization in Asia, Africa and Latin America*, 55(10), 19025-19044.
- Bre, F., Gimenez, J. M., and Fachinotti, V. D. (2018). Prediction of wind pressure coefficients on building surfaces using artificial neural networks. *Energy and Buildings*, 158, 1429–1441.
- Chen, M., Bai, Y., Lee, J. D., Zhao, T., Wang, H., Xiong, C., and Socher, R. (2020). Towards Understanding Hierarchical Learning: Benefits of Neural Representations. In *the 34th Conference on Neural Information Processing Systems (NeurIPS)* (pp.3114–3124). Vancouver: Canada.
- Cubuk, E. D., Zoph, B., Shlens, J., and Le, Q. V. (2020). RandAugment: Practical automated data augmentation with a reduced search space. In *Proceedings of the IEEE/CVF Conference on Computer Vision and Pattern Recognition Workshops* (pp.702–703). Vancouver: Canada.

- Dai, W., and Berleant, D. (2019). Benchmarking Contemporary Deep Learning Hardware and Frameworks: A Survey of Qualitative Metrics. In **2019 IEEE First International Conference on Cognitive Machine Intelligence (CogMI)** (pp.148-155). Los Angeles, CA: USA.
- Dutta, M., Sujana, R.I., Mojumdar, M. U., Chakraborty, N. R., Marouf, A. A., Rokne, J. G., and Alhajj, R. (2024). Rice Leaf Disease Classification A Comparative Approach Using Convolutional Neural Network (CNN), Cascading Autoencoder with Attention Residual U-Net (CAAR-U-Net), and MobileNet-V2 Architecture. **Technologies** 2024, 12(11), 1-15. doi: 10.3390/technologies12110214
- Fawaiq, M. N., Utami, E., and Ariatmanto, D. (2023). Rice Plant Disease Detection with Data Augmentation Using Transfer Learning. **International Journal of Research Publication and Reviews**, 4(4), 2195-2199.
- Haque, Md. E., Rahman, A., Junaed, I. and Hoque, S. U. (2022). Rice Leaf Disease Classification and Detection Using YOLOV5. In **International Conference on Digital Image Computing: Techniques and Applications (DICTA)** (pp.516-522). Sydney, New South Wales: Australia.
- Hossain, S.M.M., Deb, K., Dhar, P.K., and Koshiba, T. (2021). Plant Leaf Disease Recognition Using DepthWise Separable Convolution-Based Models. **Symmetry** 2021, 13, 511. Retrieved from <https://www.mdpi.com/2073-8994/13/3/511>. doi.org/10.3390/sym13030511
- Hou, Q., Zhou, D., and Feng, J. (2021). Coordinate Attention for Efficient Mobile Network Design. In **IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)**, 13708-13717. Online. Retrieved from <https://ieeexplore.ieee.org/xpl/conhome/9577055/proceeding?sortType=vol-only-seq&isnumber=9577056&searchWithin=Coordinate%20Attention%20for%20Efficient%20> doi.org/10.1109/CVPR46437.2021.01350
- Howard, A. G., Zhu, M., Chen, B., Kalenichenko, D., Wang, W., Weyand, T., ... Adam, H. (2017). **MobileNets: Efficient Convolutional Neural Networks for Mobile Vision Applications**. Retrieved from https://www.researchgate.net/publication/316184205_MobileNets_Efficient_Convolutional_Neural_Networks_for_Mobile_Vision_Applications. doi.org/10.48550/arXiv.1704.04861
- Howard, A., Sandler, M., Chu, G., Chen, L. C., Chen, B., Tan, M., ... Adam, H. (2019). Searching for MobileNetV3. In **Proceedings of the IEEE/CVF International Conference on Computer Vision (ICCV)** (pp.1314-1324). Seoul: South Korea.
- Hu, J., Shen, L., Albanie, S., Sun, G., and Wu, E. (2018). Squeeze-and-Excitation Networks. In **IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)** (pp.7132-7141). Salt Lake City, Utah: USA.
- Kanjanamaneesathian, M., Chumthong, A., Pengnook, A., and Wiwattanapatapee, R. (2009). Bacillus megaterium Suppresses Major Thailand Rice Diseases. **Asian Journal of Food and Agro-Industry**, Special Issue, S154-S159.
- Minaee, S., Boykov, Y., Porikli, F., Plaza, A., Kehtarnavaz, N., and Terzopoulos, D. (2023). A Comprehensive Survey of Image Augmentation Techniques for Deep Learning. **Pattern Recognition**, 137, 109347. Retrieved from <https://www.sciencedirect.com/science/article/pii/S0031320323000481>. doi.org/10.1016/j.patcog.2023.109347

- Mumuni, A., and Mumuni, F. (2022). Data augmentation: A comprehensive survey of modern approaches. *Array*, 16, 1-27. doi: 10.1016/j.array.2022.100258
- Rimi, S. A., Chowdhury, J. U., Abdullah, R., Ahmed, I., Mim, M. A., and Rahman, M. S. (2025). **Empowering Agricultural Insights: RiceLeafBD - A Novel Dataset and Optimal Model Selection for Rice Leaf Disease Diagnosis through Transfer Learning Technique**, 1-24. doi: 10.48550/arXiv.2501.08912
- Sandler, M., Howard, A., Zhu, M., Zhmoginov, A., and Chen, L. C. (2018). MobileNetV2: Inverted Residuals and Linear Bottlenecks. In *IEEE/CVF Conference on Computer Vision and Pattern Recognition (CVPR)* (pp.4510-4520). Salt Lake City, Utah: USA.
- Spadaro, D., Agusti, N., Ortega, S. F., and Hurtado Ruiz, M. A. (2020). Diagnostics and Identification of Diseases, Insects and Mites. In *Integrated Pest and Disease Management in Greenhouse Crops* (pp.231–258). Cham: Switzerland.
- Szegedy, C., Vanhoucke, V., Ioffe, S., Shlens, J., and Wojna, Z. (2015). Rethinking the Inception Architecture for Computer Vision. In *2016 IEEE Conference on Computer Vision and Pattern Recognition (CVPR)* (pp.2818-2826). Las Vegas, NV: USA.
- Tan, M., and Le, Q. V. (2019). EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks. In *Proceedings of the 36th International Conference on Machine Learning (ICML)* (pp.6105-6114). Long Beach: California.
- Worasit, T., Phatrapornnant, T., Toojinda, T., Sinthupinyo, W., Kiratiratanapruk, K., Temniranrat, P., and Patarapuwadol, S. (2022). Rice bacterial blight and blast diseases recognition using deep learning techniques. *Khon Kaen Agriculture Journal*, 50(1), 216-228.
- Xu, M., Park, J.-E., Lee, J., Yang, J., and Yoon, S. (2024). Plant disease recognition datasets in the age of deep learning: Challenges and opportunities. *Frontiers in Plant Science*, 15, 1-13. doi: 10.3389/fpls.2024.1452551
- Yang, S., Liu, X., Dong, X., and Fu, B. (2024). Mini-DA: Improving Your Model Performance through Minimal Data Augmentation using LLM. In *Proceedings of the Fifth Workshop on Data Science with Human-in-the-Loop (Language Advances)* (pp.25–30). Mexico City: Mexico.